⑩ 日本国特許庁(JP)

①特許出願公開

⑫ 公 開 特 許 公 報 (A)

昭60-200300

(5) Int Cl. 4 G 10 L 5/06 識別記号

庁内整理番号 8221-5D

❸公開 昭和60年(1985)10月9日

審査請求 未請求 発明の数 1 (全9頁)

音声の始端・終端検出装置

> 創特 願 昭59-56622

❷出 □ 願 昭59(1984)3月23日

@発 明 井 秀 者

川崎市多摩川区東三田3丁目10番1号 松下技研株式会社 内

79発 明 井 窳 川崎市多摩川区東三田3丁目10番1号 松下技研株式会社

内

79祭 明 者 見. 昌 克 川崎市多摩川区東三田3丁目10番1号 松下技研株式会社

切出 願 人 松下電器産業株式会社 門真市大字門真1006番地

弁理士 中尾 70代理 人 敏男 外1名

1、発明の名称 音声の始端・終端検出装置

2、特許請求の範囲

- (1) 音声を含む信号から一定時間長の区間毎に信 身のエネルギーとスペクトル形状を表わす特徴 量を抽出する特徴量抽出部と、前配特徴量を用 いて入力された信号が有音であるか無音である か一定時間長の区間毎に判定する有音・無音判 定部と、前配有音・無音の判定結果の時系列を 用い判定結果の持統時間により音声の始端・終 端の候補を検出する始端・終端候補検出部と、 始端・終端候補の前後における信号のエネルギ - 変化とスペクトルの変化の大きさを用いて始 端・終端の位置を決定する始端・終端決定部と を具備することを特徴とする音声の始端・終端 検出装置。
- (2) 信号のスペクトル形状を表わす特徴量として、 帯域フィルタ群、フーリエ変換若しくは線形予 **測分析のいすれかの方法により求められるパワ 3、発明の詳細な説明**

- --スペクトルまたは線形予測分析により得られ るLPOケブストラム係数のいずれかを用いる ことを特徴とする特許請求の範囲第1項記載の 音声の始端・終端検出装置。
- (3) 有音・無音判定部が、信号のエネルギーと二 つの閾値との比較を行う第1判定部と、無音, 無声音,有声音の三つの標準パターンと入力信 号のスペクトルとの統計的距離尺度を用いスペ クトルの類似度による判定を行う第2判定部と を備え、前記統計的距離尺度として線形判別関 数、マハラノビス距離、ペイズ判定のいずれか を用いることを特徴とする特許請求の範囲第1 項記載の音声の始端・終端検出装置。
- (4) 始端・終端決定部のスペクトルの変化の大き さを表わす特徴量として、一定時間長の区間に おけるスペクトルを表わす特徴量と前の区間の スペクトルを表わす特徴量とのユークリッド距 離を用いるととを特徴とする特許請求の範囲第 1 項記載の音声の始端・終機輸出装置。

産業上の利用分野

本発明は音声認識装置に用いられる音声の始端・ 終端の検出装置に関するものである。

従来例の構成とその問題点

音声の始端,終端の検出方法に関する従来例としては、信号のエネルギーと零交差回数を用いた方法が知られている。これは、新美康永:音声閣職、共立出版(1979),あるいは、

L.R. Rabiner and M. R. Sambur: An algorithm for determining the endpoint of isolated utterances, Bell Syst. Tech. J., (1975) に示されている。

零交差回数というのは信号の符号のみを残し、 振幅を1ビットに量子化した零交差波の一定時間 長の区間における零交差の平均回数である。音声 のようにスペクトル構造をもった信号の零交差回 数はスペクトル中の優勢な周波数成分とよく対応 する。第1図(a)~(c)は音声信号の零交差回数の分 布を示したもので、(a)は無音、(b)は無声音、(c)は 有声音の分布である。図から分るように、音声信 号の零交差回数は、有声音のように低域の周波数成分の優勢は音声では第1図(c)のように小さな値を示し、無声音のように高域の周波数成分の優勢な音声では第1図(b)のように大きな値を示す。従来法による音声の始端・終端検出方法はこの零交差回数を利用することにより信号のエネルギーは小さいが、零交差回数は大きな値をとる無声子音の検出精度を上げた方法である。

以下図面を参照しながら従来例の音声の始端・ 終端検出方法について説明する。

第2図は従来例の構成を示したものであり、第3 図は従来例における音声の始端・終端検出方法の動作を説明するための例を示したものである。 音声を含む信号は第2図に示すエネルギー算出 は そ 交差回数算出部 2 によりフレーム (例えば 1 0 msec 長)毎に信号エネルギー B(n)(nはフレーム番号)と零交差回数 Nz(n)という 2 つの特徴パラメータに変換される。 3 は信号のエネルギーレベルにより確実に音声区間であるという部分を検出する始端・終端候補決定部であり、信号

ネルギー B(n) に対対し2つの閾値 B: , B2

(B₁ > B₂)を適用し音声の始端候補 n₁、終 端 候補 n2 を求める。これは第3図(a)の例に示すよ りに、エネルギーの値がB2 を越え、かつその後 B2 以下になることなしに B1 を越えるとき、 音 脚区間に入ったとみなし、 B₂を 越えた 点を始端 候補 n, とするものである。終端候補 n2 は 時間 軸を逆にして、同様の方法で決定する。第2図の 4は音声の始端・終端決定部である。ととでは、 零交差回数算出部2で計算された信号の零交差回 数 Nz(n) と閾値 No を用いて、エネルギー R(n) は小 さいが零交差回数 Nz(n) が大きな値をとる無声音 が、始端・終端候補決定部3で定められた音声の 始端・終端候補(n1, n2) の外側にないか検査 ナる。第3図(b)の例に示すよりに、始端候補 n, より前の数フレームの区間において零交差回数 Nz(n) が閾値 Noより大となるフレームの数を数え、 その数が一定値(たとえば3)以上であれば始端 候補 n , より 前に無声音があるとみなし最初に闘 値 No を越えたフレーム ní に 始端を移す。 終端

についても同様である。ただし、第3図(b)では終端 n2 はもとのままである場合を示している。このようにして最終的な音声の始端,終端(n',, n2)が決定される。

しかし、上記のように零交差回数を用いた方法 では、エネルギーが小さく零交差回数も小さい有 声子音(例えば、/b/,/d/)などの脱落を 滅少することはできない。また、音声の始端,終 端には唇を開けたときの雑音とか呼吸音による雑 音が付加しやすい。第4図(a),(b)は上記雑音が付 加した音声のエネルギー変化を示したもので、(a) は唇の動きによる雑音が始端に付加した場合の例 として異様 (/ijoo/)という音声のパワー変化 を示し、(b)は呼吸音による雑音が始端に付加した 場合の例として出傷(/ideju/) という 音声の パワー変化を示したものである。図に示した例の よりな場合、従来例では始端は雑音部分となって しまり。とのように、従来例による方法では始端、 終端の位置を誤ってしまい音索の脱落や雑音によ る音索の付加がさけられない場合があるという欠

点がある。

発明の目的

本発明は上記欠点に鑑み、音声の脱落、雑音の 付加が少なく、位置精度の高い音声の始端,終端 検出装置を提供するものである。

発明の構成

上記目的を達成するためには、信号のエネルギーとスペクトル形状によりフレーム毎(例えば10msec)に有音・無音の判定を行なり有音・無音判定部と、フレーム毎の有音・無音判定結果の持続性により音声の始端・終端を検出する部分と、無音から有音またはその逆の有音から無音に変化する場合における信号のエネルギーの変化とスペクトルの変化の大きさという動的な特徴により始端・終端の位置を決定する部分とを備え、入力された音声を含む信号から音声の始端・終端の位置を検出するよりにしたものである。

実施例の説明

以下、本発明の実施例について図面を参照しな がら説明する。

一の2つの関値 B1、B2(B1)B2)が格納してある。また、標準パターンメモリ1 〇には、無音・無声音を判別するための線形判別関数の2種類のの線形判別関数の2種類での線形判別関数の名種類でいる。それの場面 B1、B2と2つの線形でれたの線形でない。 B2と2つの線形でない。 B2と2のの線形をは、B2と2のは、B2に2のは、B2

以上のように構成された音声の始端・終端検出 装置についてその動作を説明する。

マイク等より入力される音声を含む信号は第6図 のエネルギー抽出部 5 およびスペクトル形状抽出 部 6 によりフレーム毎にパワー P W と3 つの帯域

第5図は本発明の一実施例における音声認識装 置に組込まれた音声の始端・終端検出装置のプロ ック図を示したものである。図において5はエネ ルギー抽出部で、整流平滑回路で構成され信号の パワーをフレーム毎に抽出する。6はスペクトル 形状抽出部で、例えば、低域(250~60OHz), 中域(600~1500Hz),高域(1500 ~4000Hz)の3種類の帯域通過フィルタ群 と整流平滑回路で構成され、各帯域におけるフレ ーム毎のパワーがスペクトル情報として用いられ ている。エネルギー抽出部5とスペクトル形状抽 出部 6 とで特徴量抽出部 1 3 を構成する。 7 はマ ルチプレクサで、エネルギー抽出部6からの信号 のパワーとスペクトル形状抽出部6からの帯域フ ィルタパワーを時分割で有音・無音判定部Bへ入 力するためのものである。Bは有音・無音判定部 で、無音・無声音・有声音の判別を行うためのも のである。9,10は閾値メモリと標準パターン メモリであり有音・無音判定部8で用いられる定 数値が格納されている。閾値メモリョには、パワ

パワー Pi (l = 1 ~ 3)に 変換 される。 この PW, Pi はマルチプレクサ 7 を経て有音・無音 判定部8に入力される。有音・無音判定部8では 入力された P W , P_i (i = 1 ~ 3) の 4 つのパ ラメータを対数変換し対数パワー LPWと対数帯 娘パワー LPi(i=1~3)を求める。そして、 と閾値メモリ9と標準パターンメモリ10に格納 されている閾値 🖁 , 🔻 2 と2 つの線形判別関数の 係数とを用いて、入力されたフレームが有音であ るか無音であるかを判定する。この有音・無音判 定はまず最初に2つのエネルギー閾値 B₁ , B₂ (B₁ > B₂) と対数パワーLPWとの比較によ る判定が行なわれる。 2 つの閾値 B₁ , B₂ は LPW>B, ならば確実に有音であり、LPW<B2 ならば確実に無音であるといり値に設定されてい るため判定結果は式⑴に示すよりなものとなる。

LP W というエネルギー量を用いた判定で不定という判定結果を得た場合は、さらにスペクトル形状による有音・無音判定を行なう。 これは、低域,中域,高域の3つの帯域の対数パワー LPi

(i=1~3)をスペクトル形状を表わすパラメータとし、標準パターンメモリ1 Oに格納してある2種類の線形判別関数の係数を用い判別関数の値を計算することにより有音・無音を判定するものである。この2つの線形判別関数のうち1つは無音/無声音を判別するためのものであり、もう1つは無音/有声音を判別するためのものである。線形判別関数 P X は式(2)に示すものであり、標準パターンメモリ1 Oには式(2)の Ai(i=1~3)と LPi(i=1~3)が無音/無声音 ,

無音/有声音という2種類の線形判別関数毎に格 納されている。

式(2)における Ai は 2 つの クラスの最適 な判別を 行なりよりに設定され 2 つの クラスの級内分散、

出ではカウンタを2つとも用いている。第6図は 始端侯補検出のための処理の流れを示したもので ある。第6図は有音と判定されたフレームが6フ レーム以上連続したときその先頭のフレームを始 端侯補とするととを示している。第6図の処理イ は有音フレームのカウンタ(第6図のCOUNT), 始端侯補フレーム番号格納領域(第6図FRAMBS) そして処理フレームポジション(第6図I)の初 期化のためのリセットである。第8図処理口は処 理フレームポジションの更新 である。処理ハは処 理フレームが有音であるか無音であるかの比較に よる分岐である。処理しているフレームが有音で ある場合は有音フレームのカウンタ(COUNT) に 1 を加える(第 8 図処理ニ)。 さらに、始端侯 補フレーム番号格納領域(FRAMBS)がOにり セットされたままである場合は現在処理を行なっ ているフレームの番号(I)を格納する(処理ホ, へ)。処理トでは有音フレームのカウンタが5に なったかの判定を行なり。そして、カウンタが5 以下の場合は処理ロに戻り、カウンタが5以上に

級間分散の比である Fisher 比の最大化条件から 求められる。本実施例において、式(2)の Ai およ び LPi ははあらかじめ使用環境下で発声された音 **声データの無音・無声音・有声音を統計処理して** 求められる。そして『Xの値は入力が無音のとき 負で、入力が無声音あるいは有声音のときは正の 値をとるように設定してある。したがって、スペ クトル形状による有音・無音判定は無音/無声音 と無音/有声音の2つの線形判別関数を計算しい ずれか一方でも正の値をとるならば有音、2つと も負の値ならば無音と判定する。このようにして 得られたフレーム毎の有音・無音の判定結果は第 5 図の始端・終端候補検出部11に送られる。始 端・終端候補検出部11ではフレーム毎に得られ る有音・無音の判定結果の持続時間により音声の 始端候補および終端候補を検出する。11の始端・ 終端侯補検出部はマイクロプロセッサの2つのレ ジスタをカウンタとして用い、さらに比較演算機 能を用いて構成される。そして、始端候補検出に おいては 1 つのカウンタだけを用い、終端侯補検

なった場合は始端候補が検出されたといりことで 始端候補検出処理を終了する。処理が終了するま での間に処理へにおいて無音であるというフレー ムがあった場合は、処理チにおいて有音フレーム カウンタおよび始端侯補フレーム番号格納領域は リセットされ処理は口に戻る。有音フレームカウ ンタは無音フレームがあると処理チによりリセッ トされるため有音が連続したフレーム数のカウン タとなる。したがって、処理トの判定は有音が 6 フレーム以上連続したかの判定となる。したがっ て、音声の始端の前に唇の動きによる雑音などで 有声と判定されたフレームが2~3フレームあっ てもその後に1フレームでも無音と判定されるフ レームがあればそれは除去される。このよりにし て始端候補が検出されると次に終端候補検出のた めの処理が行なわれる。第7図は終端候補検出の ための処理の流れを示したものである。

第7図の処理イは無音フレームのカウンタ(第7図のCOUNT1)、有音フレームのカウンタ (第7図のCOUNT2) そして 終端候補フレー

ム番号格納領域(第7図 FRAMER) の初期化 のためのリセットである。第7図処理ロは処理フ レームポジション(第7図 I)の更新である。処 理へは処理フレームが有音であるか無音であるか の比較による分岐である。処理しているフレーム が無音である場合は無音フレームカウンタを更新 し、有音フレームカウンタをリセットする(処理 ニ、ホ)。さらに無音カウンタが2以上でかつ終 端フレーム番号格納領域がリセットされている場 合には無音フレームカウンタが1となったフレー ムの番号を終端候補フレームとして終端フレーム 格納領域に格納する(処理へ,卜)。処理チでは 無音フレームカウンタが30になったかの判定を 行なり。そして、無音フレームカウンタが3〇未 満の場合は処理口に戻り、30以上となった場合 は音声が終了したとみなし処理を終了する。処理 ハにおいて有音であった場合に分肢する処理り, ヌ,ルは終端侯補フレームが格納されてから有音 のフレームが何フレーム連続したかの処理で5フ レーム以上連続した場合は、音声は終了していた いとみなし処理イに戻り終端候補検出をやり直す。 有音フレームが 6フレーム未満の場合は雑音とみ なし、その区間は無音区間であるということで処 理ニにおいて無音フレームカウンタにその区間長 が加えられる。

の大きさにより最終的な始端・終端を決定する。 パワーの変化の大きさを表わすパラメータとして は式(3)に示すようにフレーム毎に得られる対数パ ワーLPWの差分値LPWDが用いられる。

 $LPWD_j = LPW_j - LPW_{j-1}$ …… 式(3) (ただし、jはフレーム番号)

また、スペクトルの変化の大きさを表わすパラメ ータとしては式(4)に示す帯域対数パワー LP_i のユ ークリッド距離 S P Dを用いる。

SPD_j = ½ (LP_{ij} - LP_{ij-1})² …… 式(4) (ただし、i は帯域を表わし、j はフレーム 番号を表わす)

LPWDというパラメータはパワーが増加している場合正の値をとり、パワーが減少している場合は負の値をとる。また、SPDは無音から有音へと変化する場合のようにスペクトルの形状が大きく変化するところでは大きな値をとる。始端の決定はまず始めにLPWDが正の値をとるフレームを始端候補から後端に向って検索する。次にLPWDが最初に正となったフレームから後2フ

レームの計るフレームの中でLPWDが正の値で SPDが最大となるフレームを求め、そのフレー ムを始端フレームと決定する。

終端の決定は、まず始めにLPWDが負の値をとるフレームを終端候補フレームから始端方向に向って検索する。次にLPWDが最初に負となったフレームから2フレーム前の計3フレームの中でLPWDが負の値でSPDが最大となるフレームを求め、そのフレームの1つ前のフレームを終端フレームと決定する。このようにして得られた始端・終端は音声認識装置にて利用される。

本実施例によれば、有音・無音判定部Bにおいてエネルギーレベルが低い入力信号に対し、線形判別関数を用い無音とのスペクトル形状の相異により有音であるか無音であるか判定する方法をとっているため、エネルギーの小さな無声子音やおっているため、エネルギーの小さな無声子音や有声子音の脱落を減少することができる。また、始端を機構検出部11において、音声の特殊性を考慮した検出を行なっているので、音声の始端・終端前後に付加された短かい雑音を取り除くこと

ができる。さらに、始端・終端決定部12では、 無音から有音あるいは逆の場合におけるエネルギ - の変化とスペクトル形状の変化の大きさを利用 して始端・終端の位置を決定しているため位置精 度の高い音声の始端・終端を得ることができる。 第8図は「土台」(/dodai/)と発声された音 声に本発明の一実施例における始端・終端検出を 適応した例で、第8図aは対数パワーLPWを示 し、bはスペクトル変化SPD、cはパワー変化 LPWD、dの実線は無音/無声音を判別する線 形判別関数の値、破線は無音/有声音を判別する 線形判別関数の値を示したものである。第8図の 例においては、始端・終端にそれぞれ雑音が見ら れる。フレーム毎の無音・有音判定部8では、 LPWがB,以上であるか、またはLPWがB,と B2 の間にある場合は d に示す二つの線形判別関 数の正負を勘案することにより、aに示すィから 口およびへから二の区間を有音と判定する。これ により始端の雑音が取り除かれる。始端・終端候 補検出部11亿おいては、有音・無音フレームの

持続性により始端候補フレームをイとし、終端候 補フレームを口とする。このときハからニの有音 区間は5フレーム未満であるため雑音と判定され る。そして、始端・終端決定部12では対数パワ -の変化 c とスペクトルの変化 b により始端イ、 終端口が決定され雑音が除去された正しい始端・ 終端の位置が得られる。あらかじめ目視による始 端・終端のラベル付けが行をわれている男性話者 1名が発声した212単語を用いて本発明の一実 施例の評価実験を行なった結果、ラベルとの差が 2フレーム以内となるものが始端で93.4%、終 端で92.9 ま、ラベルとの差が3フレーム以内と なるものが始端で9708、終端で9728とい **う結果を得た。そして、始端の音素脱落という重** 大な誤りは2単語、終端の音案脱落という重大な 誤りは2単語と少なく、また雑音の付加による誤 りはなく、良好な結果を得ることができ、本発明 による音声の始端・終端検出装置が有効に動作す ることを確めることができた。

なお、以上の説明ではスペクトル形状を表わす

パラメータとして帯域対数パワーを用い有音・無音の判定として線形判別関数を用いた場合について説明したが、スペクトル形状を表わすパラメータとして信号のフーリエ変換や線形予測分析により得られるLPCーケプストラム係数を用い、有音・無音の判定法としてペイズ判定やマハラノビス距離などの統計的距離尺度を用いても良い。

発明の効果

 た有音の持続性による始端・終端候補検出を行なっているため雑音の付加が少なく、しかもエネルギーとスペクトルの変化の大きさにより始端・終端の位置を決定するため位置精度が高いというすぐれた効果が得られる。

4、図面の簡単な脱明

第1図は従来用いられている零交差回数の分布図、第2図は従来の始端・終端検出装置のプロック図、第3図は従来の始端・終端検出装置の動作例を説明する図、第4図は従来で雑音が付加した音声のエネルギー変化を示す図、第6図は本発明の一実施例における音声の始端・終端検出装置のプロック図、第6図は本発明の一実施例における終端候補検出処理を示すフローチャート図、第8図は本発明の一実施例における動作例を説明する図である。

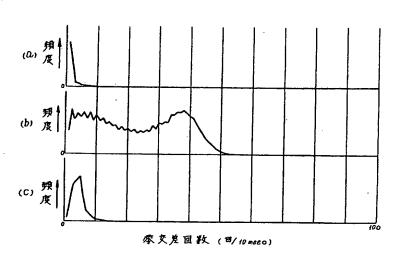
6……エネルギー抽出部、 6……スペクトル形状抽出部、 7……マルチブレクサ、 8……有音・無音判定部、 9……閾値メモリ、 1 0……標準パ

A CONTROL OF A SECURE OF THE REPORT OF THE PROPERTY OF THE RESERVE OF THE RESERVE

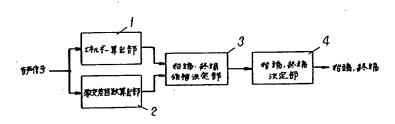
ターンメモリ、11……始端・終端候補検出部、12……始端・終端決定部、13……特徴量抽出部。

代理人の氏名 弁理十 中 尾 敏 男 ほか1名

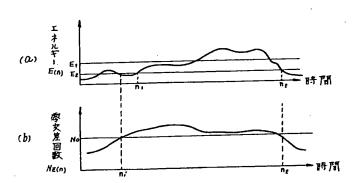
第 1 図



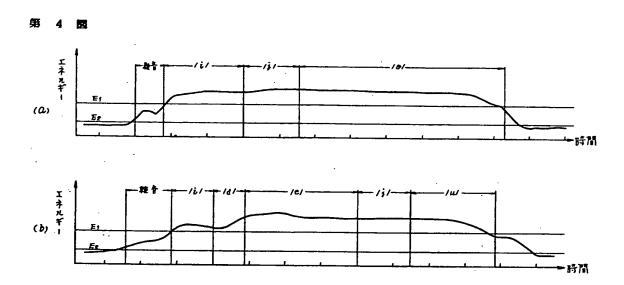


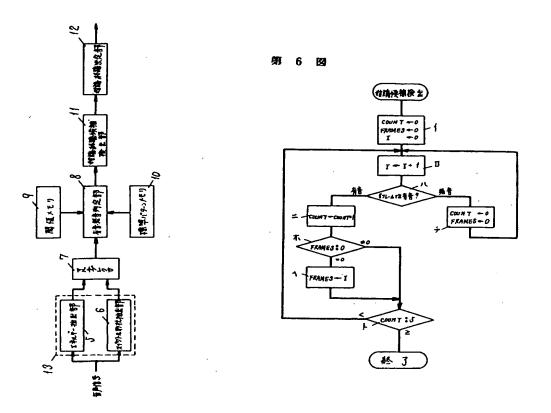


第 3 図

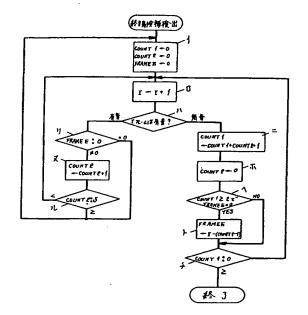


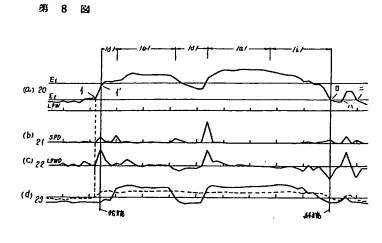
特開昭60-200300(8)





第 7 図





(72) Inventor Hideji Morii

in Matsushita Research Institute Co., Ltd.

3-10-1 Higashi Mita, Tanagawa-ku, Kawasaki-shi

(72) Inventor Ron Fujii

in Matsushita Research Institute Co., Ltd.

3-10-1 Higashi Mita, Tanagawa-ku, Kawasaki-shi

(72) Inventor Masami Hoshimi

in Matsushita Research Institute Co., Ltd.

3-10-1 Higashi Mita, Tanagawa-ku, Kawasaki-shi

(71) Applicant Matsushita Electric Industrial Co., Ltd.

1006 Kadoma, Oaza, Kadoma-shi

(74) Agent Toshio Nakao, patent attorney (and 1 other)

[the notation [?] = poorly legible or illegible]

2. Claims

- (1) A voice initiation-termination detection device that is characterized in that it has a feature quantity extraction unit that extracts from a signal that includes a voice a feature quantity that represents the energy of the signal and the shape of its spectrum in each section of a fixed duration; a sound-or-silence discrimination unit that uses said feature quantity to discriminate whether the signal that has been inputted is sounded or silent in each section of a fixed duration; an initiationtermination [?] unit that uses a time series of said sound-or-silence discrimination results to detect the [?] of the initiationtermination of the voice by the [?] of the discrimination results; and an initiationtermination decision unit that uses the size of the energy change and spectrum change of the signal before and after the initiation-termination [?] to decide the position of the initiation-termination.
- (2) A voice initiation-termination detection device as described in claim 1 that is characterized in that it uses as the feature quantity that expresses the shape of the spectrum of the signal either the power spectrum determined by the method of band filters, Fourier transformation, or

- linear prediction analysis, or the LPC [linear predictive coding] spectrum coefficient obtained by linear prediction analysis.
- (3) A voice initiation-termination detection device as described in claim 1 that is characterized in that the sounded-silent discrimination unit has a first discrimination unit that makes a comparison between the energy of the signal and two regions[?] and a second discrimination unit that uses a statistical distance scale between three [?] patterns -- silent, voiced, and voiceless -- and the spectrum of the input signal and discriminates among them based on the degree of similarity of the spectrum, and in that as said statistical distance scale it uses either a linear discrimination function, the Mahalanobis distance, or Bayes discrimination.
- (4) A voice initiation-termination detection device as described in claim 1 that is characterized in that it uses as the initiation-termination decision unit's feature quantity that represents the size of the spectrum change the Euclidean distance between the feature quantity that represents the spectrum in a section of fixed duration and the feature quantity that represents the spectrum of said section.